

ENFOQUE MULTI OBJETIVO DE LA MEJORA DE LA EFICIENCIA DE CENTRALES ELÉCTRICAS: ANÁLISIS ENERGÉTICO Y ECONÓMICO

ANA B. RUIZ

abruiz@uma.es

*Universidad de Málaga, Departamento de Economía Aplicada (Matemáticas),
Calle Ejido, 6, 29071, Málaga*

Recibido (11/04/2014)

Revisado (11/07/2014)

Aceptado (30/07/2014)

RESUMEN: Actualmente, se ha incrementado el consumo eléctrico de los servicios auxiliares de las centrales eléctricas debido a que hoy día las centrales operan mayormente a cargas parciales. En este trabajo, se presenta un estudio de optimización multiobjetivo sobre la mejora de la eficiencia energética de los servicios auxiliares. Además del ahorro energético, se consideran dos criterios económicos: la inversión económica y la Tasa Interna de Retorno para maximizar la rentabilidad de la inversión. Para resolver este problema, hemos diseñado un proceso que combina diferentes enfoques con el fin de hacer uso de las principales ventajas de cada método y de adaptar progresivamente el proceso a las preferencias del decisor. Finalmente, se ha resuelto el problema multiobjetivo asociado a un caso de estudio real utilizando el proceso diseñado. Con ello, se muestra un ejemplo de la utilidad de combinar diferentes técnicas de optimización multiobjetivo para resolver problemas reales.

Palabras Clave: Centrales eléctricas, Servicios auxiliares, Mejora de la eficiencia, Multicriterio, Optimización multiobjetivo, Algoritmos evolutivos, Punto de referencia.

ABSTRACT: The auxiliary services of power plants have raised their energy consumption given that, nowadays, power plants usually operate at partial loads. This paper presents a multiple criteria study about the efficiency improvement of the auxiliary services through a series of strategies. Besides the energy savings, two economic criteria are considered: the economic investment required and the Internal Rate of Return to maximize the profitability of the investment. In order to solve this multiobjective problem, we have developed a scheme which combines several approaches in order both to make use of the main advantages of each method and to progressively adapt the solution process to the decision maker's preferences. Finally, we solve the multiobjective problem associated to a real case study using the scheme designed. With this case study, we show the usefulness of the scheme proposed, and we highlight the importance of an understandable feedback and an adaptive process.

Keywords: Power plants, Auxiliary services, Efficiency improvement, Multiobjective optimization, Evolutionary algorithms, Reference point.

Extended Summary

Nowadays, countries depend on electricity for their development, meaning that energy is, as a final term, the motor of current societies. However, energy consumption and electricity generation are themselves among the main reasons for some environmental problems, such as CO_2 emissions, global warming, pollution or depletion of the most used sources of energy. Therefore, one of the main challenges the whole humanity faces is to assure the energy supply taking into account the economic, social and environmental sustainability. But most of the electricity consumed nowadays is generated in large power plants, some of which were built many years ago without taking into account good efficiency practices. Furthermore, the new situation of the electricity market has forced these power plants to operate at partial loads, at which they are specially inefficient, in order to participate in the frequency regulation.

The auxiliary services of thermal power plants are usually formed by a series of engines working in high and low tension modes, which are needed for the operation of the plant. Typically, in old power plants, these components were designed to be reliable systems when the plant was operating at full load, but currently their poor efficiency is particularly acute at partial loads. For example, high efficiency electric motors are rarely used, capacitor banks are hardly ever employed to improve the low power factor of the components, and it is a common practice to use dampers and control valves to regulate the air and water flows in fans and pumps, respectively, instead of using variable speed drives, which are highly recommended since they adjust the flow required to what is actually demanded at each moment.

While they are not the main components of the plant, the energy consumption of the auxiliary services is often significant (among 6 – 8% of the total electricity generation in fossil-fuel power plants, and among 4 – 6% in nuclear power plants (Fernández (1993))). A number of studies related to thermodynamics try to increase the efficiency of thermal power plants through the thermal enhancement of the turbine or the boiler (i.e., Min and Rowe (2007)), but relatively little attention has been paid to the improvement of the efficiency of the auxiliary services. In this regard, ABB Ltd. Swizerland (2009) and Huang and Edwards (2003) analyse the performances of some of the efficiency improvements that can be carried out in the auxiliaries, but only energetic criteria are considered.

The energy consumption in the auxiliary systems can be reduced by implementing a series of strategies, like replacing current motors by high efficiency ones, installing variable speed drives and/or installing capacitors in different parts of the network. These efficiency improvements have a direct impact on the electricity consumption and losses of the auxiliary systems, what implies a reduction of the electricity required for the operation of the plant. The benefit is twofold: given that the fuel consumption required for the plant operation is reduced, on the one hand, the operation costs are reduced, and on the other hand, the CO_2 emissions decrease, in turn, for the same final electricity production.

However, these strategies can be implemented in different parts of the auxiliaries and there is a wide range of possible combinations among them. In this paper, we study the multiobjective optimization problem that emerges when we want to implement the most adequate of the three strategies mentioned before in the auxiliary systems of a power plant. As previously said, the main motivation of the problem is to increase the efficiency of the auxiliaries. Therefore, the problem proposed maximizes the energy saving achieved when some of the previous policies are implemented. Obviously, if we were only interested in maximizing the energy saving (or minimizing the CO_2 emissions), the solution would be trivial: all the strategies should be implemented in all the elements involved. But there are other issues we should consider to determine which are the most profitable solutions among the wide range of improvement options. We cannot overlook the investment cost of implementing such strategies, which may be very high and has to be minimized.

Moreover, as saving some energy implies a reduction of the electricity production costs, a further economic analysis must be considered in order to maximize the profitability of the initial investment. One of the most widely used economic indexes to analyse the profitability of an investment in a given period of time is the Internal Rate of Return (IRR), which is the rate at which an initial investment is recovered by the benefits in a fix period of time. Then, apart from maximizing the energy saving and minimizing the investment cost, the IRR of the investment is also evaluated and maximized.

We have proposed a mathematical model for the problem described before. Given that the whole auxiliary system is interconnected, each particular improvement decision on any element influences the energy consumption of the rest of the elements in the network. This fact implies that some of our objective functions are discontinuous, and even they require a black-box simulator to be evaluated. Besides, the decisions to be made are represented by both binary and continuous variables, which also complicates the solution process. Moreover, the mathematical model proposed has been designed in order to be applied to the auxiliaries of any power plant. Thus, the number of decision variables cannot be known beforehand and it may be very high, because it depends on the number of elements and on the configuration of the auxiliary services considered.

Our main purpose is to solve the problem associated to a case study together with a real decision maker (DM) from the Endesa Generation S.A. company, which supported part of this study. As explained in Belton et al. (2008), in an interactive decision making process, we have to pay especial attention to how and what the DM learns about the problem itself. By learning about the problem and about one's preferences, the DM becomes more confident when making decisions during the process, and (s)he is able to foresee what may happen in the next steps. But, as the DM learns from the information given, the process must also be adapted and updated accordingly to the DM's expectations, in order to guide the search for the preferred solution.

For these reasons, in order to solve our multiobjective optimization problem, we followed a solution process which combined several multiobjective optimization techniques. Our aim was to make use of the main advantages of each technique, and to overcome their drawbacks by integrating them in a global procedure. To achieve this, we distinguished two different phases in the solution process: a preliminary phase and an interactive phase.

In the preliminary phase, we desired to analyse the conflict degree among the objective functions, so we approximated and studied the set of Pareto optimal solutions of the problem from an overall perspective. For this aim, *Evolutionary Multibjective Optimization (EMO)* algorithms are specially suitable, because of their ability to approximate the whole set of Pareto optimal solutions in just one run, and to handle complex multiobjective problems with different types of variables and objectives (Deb (2001), Coello et al. (2007), Zhou et al. (2011)). In our solution process, we applied the evolutionary algorithm NSGA-II (Deb et al. (2002)). From the set of nondominated solutions obtained, we could distinguish two kinds of compromise solutions: solutions with high energy savings, which required high investments and reached low IRR values, and solutions with high IRR values, requiring low investments and achieving small energy savings.

The set of solutions generated by NSGA-II was too large to let the DM make a final solution. In order to study in depth only the region of interest of the set of Pareto optimal solutions, next the interactive phase made use of information about the DM's preferences. These preferences were expressed by means of a reference point containing desirable objective function values. Since the DM may be initially doubtful about which reference point really expresses her/his preferences and properly represents her/his region of interest, we designed a process which let him analyse several reference points before selecting the final one. This process was based on the minimization of an achievement scalarizing function (Luque et al. (2012)) over the set of solutions generated by the NSGA-II, for different reference points given by the DM. In our case study, after several iterations,

the DM could find an interesting reference point. Despite the low computational effort required, this stage was really useful in practice, since the DM could select a reference point being aware of what could and could not be achieved.

Finally, using the reference point selected, we employed a preference-based EMO algorithm to obtain a set with a small number of nondominated solutions approximating just the region of interest. The region of interest is formed by the subset of Pareto optimal solutions which best fit the reference point. For this, the preference-based EMO algorithm WASF-GA (Ruiz et al. (2015)), which is based on the reference point preferential scheme, was used. The solutions obtained in the case study enabled the DM to realise that different trade-off solutions could be achieved according to his preferences. Actually, he found two kinds of trade-off solutions according to the reference point selected: solutions with higher IRR values but lower energy savings and higher investments, and solutions with higher energy saving which required a sacrifice of the IRR values and the investment. Afterwards, two new runs of WASF-GA were taken in order to narrow down the search towards the region where the solutions with the higher energy savings lay. Finally, the DM could find his most preferred solution by selecting the solution with the highest energy saving from the set of solutions generated by WASF-GA in the last simulation.

With the solution process designed, the DM reached a satisfactory solution for the problem because he gained a global understanding of the problem progressively, but also because the process considered his preferences interactively. Initially, he could learn about the trade-offs between the objectives; next, he defined his preferences being aware of what could and could not be achieved; and finally, he found the final solution by analysing the trade-offs among a set of nondominated solutions that represented his region of interest. We could see that what was gained from an approach was not obtained from the others, and, in practice, the combination of the multiobjective optimization methodologies used was decisive to reach a satisfactory solution of the problem. This fact highlights the potential and usefulness of interactive multiobjective optimization to solve real-life decision making problems.

Regarding the problem, it was shown that the solutions with the highest energy savings were the least profitable ones, and the solutions with the highest IRR values were those which saved the least amount of energy. With this case study, we have shown that this problem cannot be studied just taking into account the energy saving criterion, since the economic criteria play an important role for finding a satisfactory solution. The DM could analyse the solutions found not only from the energy perspective, but also from the economic point of view. Indeed, given that we obtained very high IRR values, we can conclude that the investment required for the improvement of the auxiliary services is highly profitable, specially when the performance of a power plant has to be improved at partial loads.

1. Introducción

Uno de los principales desafíos actuales de la sociedad es el poder asegurar el suministro de energía de forma sostenible económica, social y medioambientalmente. Actualmente, se están impulsando nuevas prácticas energéticas que ayudan a disminuir la degradación del medio ambiente debido al consumo de y la producción de electricidad. Por ejemplo, la Comisión Europea lanzó en 2008 un paquete de objetivos medioambientales que deberán alcanzarse para 2020 (Commission (2012)). Dichas medidas están encaminadas a reducir un 20% las emisiones de gases de efecto invernadero, reducir un 20% el consumo de energía mejorando el rendimiento energético y conseguir atender el 20% de las necesidades energéticas mediante el uso de energías renovables. Además de las consecuencias medioambientales, la producción de energía representa un sector muy importante en las economías actuales, además de que el progreso de muchos países en vías de desarrollo depende directamente de la disponibilidad de fuentes de energía económicas y en cantidades suficientes.

La mayor parte de la electricidad consumida hoy día se genera en grandes centrales térmicas, algunas de las cuales se construyeron hace años sin tener en cuenta buenas prácticas en términos de eficiencia (ABB Ltd. Swizerland (2009)). La mayoría fueron diseñadas para trabajar eficientemente a máxima carga, pero las circunstancias actuales del mercado energético han hecho que dichas centrales operen a cargas parciales un alto porcentaje del tiempo. Sin embargo, a dichas cargas, no se alcanzan buenos niveles de eficiencia energética. Actualmente, gran parte de las medidas adoptadas para incrementar la eficiencia energética de dichas centrales se centran principalmente en mejorar elementos con un impacto directo en la generación de electricidad, como el generador o la turbina (Min and Rowe (2007)), pasando por alto la mejora de otros elementos necesarios para el propio funcionamiento de la central, pero que no son tan vitales como los anteriores. Entre ellos están los denominados *servicios o sistemas auxiliares*, necesarios para satisfacer funciones de suministro de agua, aire o carburante, o de evacuación de residuos. Normalmente, los equipos auxiliares están compuestos por varios accionamientos¹ que funcionan a media y baja tensión, como por ejemplo molinos de carbón, bombas de agua de alimentación, bombas de condensado, bombas de circulación de agua, ventiladores de aire primario, ventiladores de tiro inducido o ventiladores de tiro forzado. Junto a ellos, también forman parte de los servicios auxiliares los cables y transformadores de potencia necesarios para la conversión y distribución de la energía eléctrica.

Aunque no son los principales componentes de la central, los equipos auxiliares consumen una parte de la electricidad producida por la central. Según Fernández (1993), los auxiliares consumen entre el 6% y el 8% de la generación total en centrales térmicas convencionales, mientras que en una central nuclear consumen entre el 4% y el 6%. Pese a ello, estos equipos raramente alcanzan altos niveles de eficiencia, y es por ello que hay una necesidad de estudiar las posibles mejoras que se pueden implantar. Algunos trabajos, como ABB Ltd. Swizerland (2009) y Huang and Edwards (2003), analizan algunas de las posibles mejoras de los servicios auxiliares, pero atendiendo únicamente a criterios energéticos. En este artículo, se presenta un análisis de la mejora de la eficiencia de los servicios auxiliares desde una perspectiva multiobjetivo, atendiendo a criterios económicos y energéticos. Se demuestra que, para aumentar la eficiencia energética de una central y reducir los costes de operación, la mejora de los auxiliares representa una inversión económicamente muy rentable, especialmente cuando la central se encuentra operando a cargas parciales.

Existen ciertas estrategias que reducen el consumo los servicios auxiliares y que, por tanto, pueden contribuir positivamente al aumento de la eficiencia de todo el sistema. Entre ellas, podemos

¹Un accionamiento es la combinación de una fuerza motriz (motor eléctrico), un acoplador y una bomba o un ventilador.

mencionar la sustitución de los motores actuales por motores de alto rendimiento, la instalación de variadores de velocidad como método de regulación del caudal en bombas y ventiladores, y la instalación de condensadores en diferentes partes de la red. El impacto en el consumo energético de los auxiliares que introducen estas mejoras resulta evidente, ya que implican una reducción de la energía eléctrica necesaria para el funcionamiento de la central. El beneficio es doble: dado que el consumo de combustible necesario para el funcionamiento de la central se reduce, por una parte, los costes de operación se reducen, y por otra parte, las emisiones de CO_2 disminuyen, a su vez, para la misma producción final de electricidad.

Ahora bien, dependiendo de si estas estrategias se llevan a cabo en todos los elementos susceptibles de mejora o sólo en algunos, el ahorro energético obtenido puede variar considerablemente y, por ello, es necesario estudiar detenidamente cuál es la mejor combinación de estrategias posible. En este artículo, se pretende estudiar el problema de optimización multiobjetivo que surge cuando se intenta determinar qué combinación de las estrategias anteriormente mencionadas se ha de implementar en los servicios auxiliares de una central eléctrica, atendiendo a criterios no sólo energéticos sino también económicos. Aunque la principal motivación del problema es mejorar la eficiencia energética de los sistemas auxiliares, no podemos pasar por alto el coste económico que supone la implementación de estas prácticas, ya que puede ser muy elevado y tiene que ser estudiado. Por ello, el segundo objetivo a minimizar es la inversión económica necesaria. Ahora bien, dado que el ahorro energético implica una reducción de los costes de producción, es necesario analizar económicamente la rentabilidad de la inversión inicial en un período dado de tiempo. Para ello, junto a los dos criterios anteriores, maximizaremos también la Tasa Interna de Retorno (TIR)² de la inversión. Este problema surgió a raíz de un contrato I+D+i con la empresa Endesa Generación S.A., una de la principales compañías eléctricas de España.

Existen muchas aplicaciones de la optimización multiobjetivo a problemas relacionados con el sector energético. Por ejemplo, Cabello et al. (2014), Diakoulaki et al. (2005), Laken (2007), Zhou et al. (2006) resuelven problemas de optimización multiobjetivo de planificación de producción energética mediante técnicas de la *Toma de Decisiones Multicriterio (Multiple Criteria Decision Making (MCDM))* (Miettinen (1999)). Otra rama de la optimización multiobjetivo empleada para resolver problemas reales de este tipo es la *Optimización Multiobjetivo Evolutiva (Evolutionary Multiobjective Optimization (EMO))*, cuyos algoritmos están basados en poblaciones de soluciones que se transforman a través de operadores basados en la evolución natural de las especies (Deb (2001), Coello et al. (2007)). Los trabajos presentados en Cabello et al. (2011) y Deb et al. (2012) hacen uso de este tipo de algoritmos para determinar el tamaño óptimo de centrales eléctricas solares, teniendo en cuenta criterios económicos. En Ahmadi et al. (2011), se hace un análisis multiobjetivo del impacto exergoeconómico y medioambiental de varias centrales eléctricas de ciclo combinado mediante un algoritmo genético. También se emplean estas técnicas en Dipama et al. (2010) para optimizar el consumo energético, la eficiencia y el impacto medioambiental de centrales eléctricas, y en Di Barba and Mognaschi (2009) para estudiar el diseño óptimo de un generador. Meza et al. (2009) resuelve un problema multiobjetivo asociado a la creación de nuevas centrales eléctricas y a la planificación de generación de energía a través de algoritmos evolutivos. Asimismo, Toffolo and Lazzaretto (2002) hacen uso de estos algoritmos de optimización para resolver un problema de diseño de centrales térmicas atendiendo a criterios económicos y exergéticos.

Para optimizar el ahorro energético, la inversión económica y el TIR de la inversión en el problema que nos ocupa, se ha diseñado un modelo matemático que permite estudiar la mejora de la

²La Tasa Interna de Retorno (TIR) estudia a qué interés se recupera una inversión a través de los beneficios obtenidos en un periodo fijo de tiempo.

eficiencia energética de los servicios auxiliares de cualquier central térmica. En el modelo diseñado, se tiene en cuenta que, en general, todos los servicios auxiliares de una central están interconectados entre sí, así que la mejora energética de un elemento influye en el consumo del resto de elementos en la red. Es por ello que la modelización del problema no resulta sencilla. Algunas de las funciones objetivo son discontinuas e incluso es necesario usar un simulador de tipo caja negra para obtener el ahorro energético obtenido al implementar ciertas estrategias. Además de ello, se consideran variables de decisión continuas y binarias para determinar la implementación de las estrategias anteriores en los elementos correspondientes, además de que el número de dichas variables aumenta con el número de elementos que constituyen los servicios auxiliares y su distribución en la red.

Dado que el objetivo de este trabajo es resolver el problema multiobjetivo planteado junto con un decisor real de la empresa Endesa Generación S.A. para un caso de estudio concreto, es muy importante prestar especial atención al proceso de resolución seguido. En general, como se explica en Belton et al. (2008), la resolución de un problema de optimización multiobjetivo debe permitir al decisor comprender las características del problema en profundidad y entender el tipo de relación existente entre los criterios considerados. De esta manera, el decisor puede interpretar el problema de una manera más realista, ajustando sus expectativas al tipo de soluciones óptimas que realmente se pueden obtener. Además, para poder encontrar la solución Pareto óptima final de un problema de optimización multiobjetivo, es imprescindible conocer información sobre las preferencias del decisor e incorporar dicha información preferencial en el proceso de resolución de manera interactiva. De esta forma, el proceso permite al decisor obtener soluciones Pareto óptimas que se ajustan a sus preferencias lo mejor posible, dándole asimismo la posibilidad de redefinir dichas preferencias en función de la información proporcionada para obtener nuevas soluciones.

Teniendo en cuenta todo lo anterior, se ha diseñado un proceso de resolución para el problema de optimización considerado que pretende combinar varias técnicas de optimización. El objetivo no es otro que permitir que el decisor obtenga información sobre el problema en sí de forma progresiva, para que finalmente pueda converger hacia la solución Pareto óptima que mejor se ajuste a sus preferencias. En la fase inicial del proceso de resolución, se ha aplicado un algoritmo evolutivo para obtener una aproximación de todo el conjunto de soluciones Pareto óptimas que nos permita analizar el problema en su globalidad y estudiar el grado de conflicto entre las funciones objetivo. Los algoritmos evolutivos de optimización multiobjetivo son especialmente apropiados para el tipo de problema que nos ocupa, dado que han demostrado ser capaces de resolver problemas de optimización multiobjetivo complejos con funciones objetivo y variables de diferente naturaleza (Deb (2001), Zhou et al. (2011)). Dado que el conjunto de soluciones obtenidas con el algoritmo evolutivo considerado es muy extenso, resulta necesario introducir preferencias en el proceso que posibiliten reducir el conjunto de soluciones para que así el decisor pueda elegir la solución final. Por ello, seguidamente, se ha diseñado una fase interactiva que consta de dos etapas claramente definidas. El objetivo de la primera etapa es ayudar al decisor a definir sus preferencias, las cuales se expresan mediante un punto de referencia. Inicialmente el decisor puede no conocer qué tipo de soluciones generará un punto de referencia u otro, ni tampoco si dichas soluciones son o no deseables bajo su criterio. De ahí, surge la necesidad de diseñar un proceso de ayuda que le permite estudiar varios puntos referencia, y que está basado en una función escalarizada de logro (Luque et al. (2012)) y en la información sobre el conjunto de soluciones Pareto óptimas proporcionada en la fase inicial. Posteriormente, en la segunda etapa de la fase interactiva, la información preferencial definida en la primera etapa se incorpora en un algoritmo evolutivo basado en preferencias (Coello (2000), Branke (2008), Jaszkiwicz and Branke (2008)), cuyo objetivo es focalizar la búsqueda de nuevas soluciones únicamente en el subconjunto de soluciones Pareto óptimas que obedecen en mayor medida dichas preferencias.

A través del proceso de resolución diseñado, el decisor se encuentra en una situación adecuada para tomar una decisión final, ya que a través de la primera fase obtiene una visión global de la interrelación entre las funciones objetivo y la segunda fase interactiva finalmente le proporciona un subconjunto reducido de soluciones que se ajustan a las preferencias previamente definidas. Con todo este proceso interactivo, este trabajo pretende demostrar la utilidad de las diferentes técnicas de optimización multiobjetivo empleadas. Además, se persigue resaltar el potencial de la combinación de diferentes metodologías de optimización en un proceso de resolución, para explotar al máximo las ventajas de cada una de ellas y solventar las deficiencias de las mismas.

A continuación, la Sección 2 presenta conceptos básicos de optimización multiobjetivo y una breve descripción de las técnicas empleadas para resolver el problema. En la Sección 3, se expone el modelo matemático que modela el problema que nos ocupa, analizando las funciones objetivo, las variables de decisión y las restricciones incluidas. El proceso de resolución diseñado y los resultados obtenidos en un caso de estudio concreto se describen en la Sección 4. Por último, en la Sección 5, describimos las conclusiones más relevantes del estudio realizado.

2. Conceptos

Como el problema ante el que nos encontramos, muchos problemas de nuestra vida diaria tratan de optimizar conjuntamente varios criterios. Cuando es posible expresar matemáticamente los criterios a optimizar y las restricciones del problema, nos encontraremos ante un *problema de optimización multiobjetivo*, que tiene la siguiente formulación general:

$$\begin{array}{ll} \text{minimizar} & \{f_1(\mathbf{x}), f_2(\mathbf{x}), \dots, f_k(\mathbf{x})\} \\ \text{sujeto a} & \mathbf{x} \in S, \end{array} \quad (1)$$

siendo $f_i : S \rightarrow \mathbb{R}$, para cada $i = 1, \dots, k$, las k ($k \geq 2$) *funciones objetivo* a minimizar y S el *conjunto factible* de *vectores de decisión* $\mathbf{x} = (x_1, x_2, \dots, x_n)^T$. La imagen del conjunto factible $Z = \mathbf{f}(S)$ en el espacio de objetivos \mathbb{R}^k está compuesta por *vectores objetivo* de la forma $\mathbf{z} = \mathbf{f}(\mathbf{x}) = (f_1(\mathbf{x}), f_2(\mathbf{x}), \dots, f_k(\mathbf{x}))^T$, para algún $\mathbf{x} \in S$.

A la hora de resolver estos problemas, normalmente, no es posible encontrar una solución en la que todos los objetivos alcancen sus óptimos individuales simultáneamente, dado que suele existir cierto grado de conflicto entre los objetivos que se pretenden optimizar. Sin embargo, existe un conjunto de soluciones para las que no se puede mejorar el valor de ningún objetivo sin empeorar algún otro. Son las denominadas soluciones Pareto óptimas. Dados $\mathbf{z}, \mathbf{z}' \in \mathbb{R}^k$, diremos que \mathbf{z} *domina a* \mathbf{z}' si y solo si $z_i \leq z'_i$ para todo $i = 1, \dots, k$, y existe algún $j = 1, \dots, k$ tal que $z_j < z'_j$. Si \mathbf{z} no domina a \mathbf{z}' ni \mathbf{z}' domina a \mathbf{z} , diremos que \mathbf{z} y \mathbf{z}' son (*mutuamente*) *no dominados*. Ahora bien, diremos que un vector de decisión $\mathbf{x} \in S$ es una *solución Pareto óptima* si no existe ningún $\mathbf{x}' \in S$ tal que $\mathbf{f}(\mathbf{x}')$ domine a $\mathbf{f}(\mathbf{x})$. Diremos que el vector objetivo correspondiente $\mathbf{z} = \mathbf{f}(\mathbf{x})$ es *no dominado*. El conjunto de todas las soluciones Pareto óptimas se conoce como *conjunto óptimo de Pareto* y se denota por E , y su imagen en el espacio de objetivos, $\mathbf{f}(E)$, se denomina *frente óptimo de Pareto*.

Los rangos de valores de las funciones objetivo están definidos por los vectores ideal y nadir, que representan los mejores y los peores valores que cada función objetivo puede tomar en el espacio de objetivos, respectivamente. El *vector ideal*, $\mathbf{z}^* = (z_1^*, \dots, z_k^*)^T$, contiene los menores valores que cada función objetivo puede alcanzar y se obtiene mediante la minimización de cada objetivo sobre el conjunto factible, esto es, $z_i^* = \min_{\mathbf{x} \in S} f_i(\mathbf{x}) = \min_{\mathbf{x} \in E} f_i(\mathbf{x})$ para todo $i = 1, \dots, k$. El *vector nadir*, $\mathbf{z}^{\text{nad}} = (z_1^{\text{nad}}, \dots, z_k^{\text{nad}})^T$, está formado por los mayores valores de cada función objetivo y puede definirse como $z_i^{\text{nad}} = \max_{\mathbf{x} \in E} f_i(\mathbf{x})$ para cada $i = 1, \dots, k$. En la práctica, el vector nadir es difícil de obtener ya que lo más habitual es que el frente óptimo de Pareto sea desconocido.

Por ello, normalmente suele aproximarse (véase Miettinen (1999), Deb and Miettinen (2010), Deb, et al. (2010)).

Desde el punto de vista matemático, todas las soluciones Pareto óptimas son equivalentes, por lo que necesitamos la intervención de algún *decisor* que sea capaz de expresar ciertas preferencias que determinen la solución final del problema. La *Toma de Decisiones Multicriterio (Multiple Criteria Decision Making, MCDM)* se centra en el estudio de técnicas cuyo objetivo es ayudar al decisor a elegir la solución más adecuada en función de sus preferencias. La información preferencial puede expresarse de diversas formas (Miettinen (1999)), y una de las más simples y usadas es mediante un punto de referencia. Un *punto de referencia* es un vector del espacio de objetivos, $\mathbf{q} = (q_1, \dots, q_k) \in \mathbb{R}^k$, donde cada q_i es un *nivel de referencia* o *valor de aspiración* que el decisor desea obtener en la función objetivo f_i , para cada $i = 1, \dots, k$. En general, se considera que un punto de referencia es *alcanzable* si existe alguna solución $\mathbf{x} \in S$ cuyos valores de las funciones objetivo mejoran o igualan los correspondientes niveles de referencia simultáneamente. En otro caso, se dice que el punto de referencia es *inalcanzable*.

Muchos métodos basados en punto de referencia transforman el problema original en un problema mono-objetivo en el que se combinan las funciones objetivo con la información proporcionada por el punto de referencia. En dichos problemas mono-objetivo, se minimiza una *función escalarizada de logro* sobre el conjunto factible para obtener la solución Pareto óptima que mejor se ajusta al punto de referencia (para más información sobre funciones escalarizadas de logro, ver Miettinen and Mäkelä (2002)). Una de las funciones escalarizadas de logro más empleada está basada en la distancia L_∞ y viene dada por la siguiente expresión (Wierzbicki (1980)):

$$s(\mathbf{q}, \mathbf{f}(\mathbf{x}), \mu) = \max_{i=1, \dots, k} \{ \mu_i (f_i(\mathbf{x}) - q_i) \} + \rho \sum_{i=1}^k (f_i(\mathbf{x}) - q_i), \quad (2)$$

donde $\mathbf{q} \in \mathbb{R}^k$ es un punto de referencia, $\mu = (\mu_1, \dots, \mu_k)$ es un vector de pesos y $\rho > 0$ es un valor real suficientemente pequeño. Se puede asegurar que la solución obtenida al minimizar (2) sobre el conjunto factible S es siempre una solución Pareto óptima de (1) con trade-offs o tasas de intercambio entre los objetivos acotadas (Miettinen (1999)). En la práctica, si los pesos considerados son estrictamente positivos, minimizar esta función de logro significa proyectar el punto de referencia sobre el frente óptimo de Pareto en la dirección determinada por los valores inversos del vector de pesos.

En diversos estudios (Miettinen and Mäkelä (2002, 1999), Buchanan and Gardiner (2003), Luque et al. (2009), Ruiz et al. (2009)), se defiende que, para un punto de referencia dado, no todos los métodos generan soluciones Pareto óptimas que satisfacen al decisor por igual. De hecho, sostienen que el nivel de satisfacción depende, por un lado, del vector de pesos considerado en la función de logro y, por otro lado, de si el punto de referencia es alcanzable o no. En Luque et al. (2012), se propone una nueva función denominada la *función escalarizada de logro con dos pendientes*, que permite trabajar simultáneamente con dos vectores de pesos. En la práctica, uno es considerado cuando el punto de referencia es alcanzable, y el otro cuando es inalcanzable. Para un punto de referencia $\mathbf{q} \in \mathbb{R}^k$ y cualesquiera dos vectores de pesos, $\mu^U = (\mu_1^U, \dots, \mu_k^U)$ y $\mu^A = (\mu_1^A, \dots, \mu_k^A)$, la formulación general de la función de logro de dos pendientes viene dada por:

$$\bar{s}(\mathbf{q}, \mathbf{f}(\mathbf{x}), \mu^U, \mu^A) = \bar{s}_0(\mathbf{q}, \mathbf{f}(\mathbf{x}), \mu^U, \mu^A) + \rho \sum_{i=1}^k (f_i(\mathbf{x}) - q_i), \quad (3)$$

donde $\rho > 0$ es un valor escalar suficientemente pequeño y \bar{s}_0 tiene la siguiente expresión:

$$\bar{s}_0(\mathbf{q}, \mathbf{f}(\mathbf{x}), \mu^U, \mu^A) = \max_{i=1, \dots, k} \{ \max\{ \mu_i^U (f_i(\mathbf{x}) - q_i), 0 \} + \min\{ \mu_i^A (f_i(\mathbf{x}) - q_i), 0 \} \}. \quad (4)$$

En Luque et al. (2012) se demuestra que, cuando se minimiza (3) sobre el conjunto factible S , el vector de pesos μ^A se emplea cuando \mathbf{q} es alcanzable y el vector de pesos μ^U se usa si \mathbf{q} es inalcanzable. Estos dos vectores de pesos dan lugar a dos direcciones de proyección distintas del punto de referencia sobre el frente óptimo de Pareto, que permiten reflejar las preferencias del decisor de la forma más adecuada en cada caso. La novedad de esta función de logro es que no es necesario comprobar previamente si el punto de referencia es alcanzable o no para determinar qué vector de pesos se usa, la propia formulación selecciona el más adecuado en cada caso.

Unos vectores de pesos que se pueden emplear en la función escalarizada de logro de dos pendientes son los vectores de pesos preferenciales propuestos en Luque et al. (2009). En ese trabajo, se proponen varios esquemas preferenciales para calcular pesos distintos para puntos de referencia alcanzables e inalcanzables. En uno de ellos, una vez proporcionado un punto de referencia, el decisor ha de clasificar las funciones objetivo en subconjuntos dependiendo de la importancia que conceda a cada nivel de aspiración. En concreto, el decisor ha de clasificar las k funciones objetivo en subconjuntos J_r que representan niveles de importancia $r = 1, \dots, s$, donde $1 \leq s \leq k$. Si $r < t$, alcanzar los niveles de aspiración de las funciones objetivo en el subconjunto J_r es menos importante que alcanzar los niveles de aspiración de los objetivos en el subconjunto J_t . Hay que resaltar que el decisor no ha de clasificar los objetivos por niveles de importancia global, sino que se le pregunta sobre un orden de importancia local para alcanzar los niveles de aspiración del punto de referencia dado. En base a esta información, para cada $r = 1, \dots, s$ e $i \in J_r$, Luque et al. (2009) propone los siguientes vectores μ^A y μ^U para los casos alcanzable e inalcanzable, respectivamente:

$$\mu_i^A = \frac{1}{r(\mathbf{z}^{nad} - \mathbf{z}^*)}, \quad \mu_i^U = \frac{r}{\mathbf{z}^{nad} - \mathbf{z}^*}. \quad (5)$$

Para la resolución de nuestro problema, hemos empleado un algoritmo evolutivo (Deb (2001), Coello et al. (2007)). Estos algoritmos obtienen un conjunto de soluciones (mutuamente) no dominadas que aproximan lo mejor posible todo el frente óptimo de Pareto para que, posteriormente, el decisor elija la solución más deseada. En cada generación, interviene una población de soluciones, a la cual se le aplican unos operadores que intentan simular el proceso natural de evolución de las especies (selección, reproducción, mutación y elitismo). En nuestro caso, hemos empleado el algoritmo evolutivo *NSGA-II (Non-dominated Sorting Genetic Algorithm)* (Deb et al. (2002)), que ha sido aplicado con éxito a diversos problemas de optimización multiobjetivo reales (Deb (2001), Zhou et al. (2011)). En cada generación de NSGA-II, tras obtener una población de hijos al aplicar los operadores correspondientes a la población actual (población de padres), se clasifica u ordena el conjunto formado por padres e hijos en varias fronteras en base a la relación de dominancia existente entre los individuos. En concreto, la primera frontera está compuesta por las soluciones no dominadas por ninguna otra solución. Éstas soluciones se eliminan temporalmente de la población y la segunda frontera está formada nuevamente por las soluciones no dominadas por ninguna otra. De esta manera, se procede sucesivamente hasta que todas las soluciones han sido clasificadas en alguna frontera. Finalmente, las soluciones que forman la población para la siguiente generación son aquellas que se encuentran en las primeras fronteras hasta completar el tamaño de la nueva población. Si hay más soluciones en la última frontera considerada que el espacio disponible en la población, se eligen aquellas soluciones de dicha frontera con la menor distancia 'crowding', una medida del espacio que hay alrededor de cada solución no ocupado por ninguna otra solución del conjunto. Esta distancia crowding está diseñada para preservar la diversidad en la población. Los pasos principales de NSGA-II aparecen en el Algoritmo 1, en el que h denota la generación actual, P_h la población de individuos en la generación h y $|A|$ significa la cardinalidad de un conjunto A (véase Deb et al. (2002) para más información).

Algoritmo 1 Algoritmo NSGA-II**Entrada:** Tamaño de la población (N) y *CriterioParada*.**Salida:** Población con los mejores individuos, P .

- 1: Inicializar P_0 y $h = 0$.
- 2: **Mientras** no *CriterioParada* **hacer**
- 3: $Q_h = \text{Selección} - \text{Cruce} - \text{Mutación}(P_h)$.
- 4: $R_h = P_h \cup Q_h$.
- 5: $\text{OrdenamientoNoDominado}(R_h) = \{F_h^i, i = 1, 2, \dots\}$ (fronteras no dominadas).
- 6: $P_{h+1} = \emptyset$ y $i = 1$.
- 7: **Mientras** $|P_{h+1} \cup F_h^i| \leq N$ **hacer**
- 8: Calcular $\text{DistanciaCrowding}(F_h^i)$.
- 9: $P_{h+1} = P_{h+1} \cup F_h^i$.
- 10: $i = i + 1$.
- 11: **Fin Mientras**
- 12: Ordenar descendientemente F_h^i por $\text{DistanciaCrowding}(F_h^i)$.
- 13: Introducir en P_{h+1} los $N - |P_{h+1}|$ primeros individuos de F_h^i .
- 14: $h = h + 1$.
- 15: **Fin Mientras**
- 16: $P = F_{h-1}^1$.

Para resolver un problema de optimización multiobjetivo, no sólo basta con aproximar todo el frente óptimo de Pareto, es necesario introducir preferencias. Al aplicar un algoritmo evolutivo, obtenemos un elevado número de soluciones que nos ayudan a comprender el problema en su globalidad, pero puede resultar tremendamente difícil para el decisor encontrar una solución final al problema entre tantas soluciones. De hecho, normalmente el decisor suele estar interesado en un número reducido de soluciones Pareto óptimas que obedecen en cierto modo a sus intereses. Por ello, los denominados *algoritmos evolutivos basados en preferencias* (Coello (2000), Branke (2008), Jaszkiwicz and Branke (2008)) tienen como objetivo aproximar el subconjunto de soluciones Pareto óptimas que forman la *región de interés* definida por las preferencias del decisor. Para converger hacia la región de interés, dichos algoritmos introducen cierta información preferencial en el proceso evolutivo. De esta forma, finalmente se reduce la carga cognitiva necesaria para seleccionar la solución preferida, ya que el decisor ha de revisar y comparar menos soluciones, las cuales, a su vez, se ajustan mejor a sus preferencias.

Por todo ello, para resolver nuestro problema, tras analizar la aproximación del frente óptimo de Pareto proporcionada por NSGA-II y haber estudiado el grado de conflicto entre los objetivos, aplicamos el algoritmo evolutivo basado en preferencias denominado *WASF-GA* (*Weighting Achievement Scalarizing Function Genetic Algorithm*) (Ruiz et al. (2015)). En función de un punto de referencia \mathbf{q} dado por el decisor, su principal objetivo es aproximar la región de interés formada por las soluciones Pareto óptimas "alcanzables" desde dicho punto de referencia. Si \mathbf{q} es alcanzable, dicha región de interés está formada por las soluciones $\mathbf{x} \in E$ tales que $\mathbf{f}(\mathbf{x})$ domina a \mathbf{q} , esto es, que verifican $f_i(\mathbf{x}) \leq q_i$, para todo $i = 1, \dots, k$. Esta claro que, en este caso, éstas son las soluciones más deseables para el decisor puesto que sus valores objetivo mejoran todos los niveles de referencia simultáneamente. En el caso de que \mathbf{q} sea inalcanzable, no hay ninguna solución Pareto óptima que domine al punto de referencia y, por ello, es más difícil determinar qué soluciones serán las más atractivas para el decisor. En este caso, hemos considerado que la región de interés será la formada por las soluciones $\mathbf{x} \in E$ tales que $\mathbf{f}(\mathbf{x})$ está dominado por \mathbf{q} , esto es, que verifican $f_i(\mathbf{x}) \geq q_i$, para todo $i = 1, \dots, k$. Pese a que estas soluciones no mejoran ningún valor de referencia, los empeoran

lo menos posible. Por otro lado, aunque las soluciones que no pertenecen a esta región de interés pueden mejorar algún nivel de aspiración, necesitan sacrificar otros niveles de referencia a cambio, lo que puede no ser satisfactorio para el decisor.

La filosofía de WASF-GA está basada en la función escalarizada de logro (2). Para cualquier punto de referencia, esta función permite obtener cualquier solución Pareto óptima dentro de la región de interés definida anteriormente, variando el vector de pesos en todo el espacio de vectores de pesos (Miettinen (1999)). Por ello, WASF-GA aproxima la región de interés minimizando, en cada generación, esta función para el punto de referencia dado y usando un subconjunto de vectores de pesos. Si el decisor determina que desea generar N_μ soluciones en la región de interés, inicialmente se obtiene un subconjunto de N_μ vectores de pesos que verifican que las direcciones de proyección asociadas a ellos están lo mejor equidistribuidas posible. Ésta es precisamente la clave para generar un conjunto final de soluciones no dominadas bien distribuidas en la región de interés. Tras obtener dichos vectores, en cada generación, se clasifica el conjunto de padres e hijos en varias fronteras, teniendo en cuenta los valores de la función (2) en cada solución para el punto de referencia dado y para cada uno de los vectores de pesos generados. En concreto, la primera frontera está formada por las soluciones en las que se alcanza el menor valor de (2) para cada uno de los N_μ vectores de pesos. Estas soluciones se eliminan temporalmente y la segunda frontera se compone de las soluciones con los siguientes menores valores de (2) para cada uno de los N_μ vectores de pesos. Este proceso se repite hasta que todas las soluciones se han incluido en alguna frontera. Posteriormente, la población para la siguiente generación está compuesta por los individuos en las primeras fronteras, y si hay más soluciones en la última frontera considerada que el espacio disponible en la nueva población, se seleccionan las soluciones de dicha frontera con los menores valores de la función (2). De esta forma, en cada generación, se seleccionan aquellas soluciones más próximas al punto de referencia con respecto a (2), en cada una de las N_μ direcciones determinadas por los N_μ vectores de pesos. Los pasos principales de WASF-GA aparecen en el Algoritmo 2, en el que h denota la generación actual, P_h la población de individuos en la generación h y $|A|$ significa la cardinalidad de un conjunto A (véase Ruiz et al. (2015) para más información).

3. Modelo de Optimización Multiobjetivo

En esta sección, se describen las principales características del modelo de optimización multiobjetivo diseñado para el problema descrito en la Sección 1. Los parámetros técnicos y los datos económicos empleados han sido proporcionados por la empresa Endesa Generación S.A. y están disponibles bajo petición, aunque no se especifican en este trabajo.

Como se ha comentado en la Sección 1, hemos considerado las siguientes estrategias para la mejora de la eficiencia energética de los servicios auxiliares:

- Estrategia A: Sustitución de los motores actuales por motores de alto rendimiento, para incrementar el rendimiento de los servicios auxiliares y reducir las pérdidas de energía.
- Estrategia B: Instalación variadores de velocidad como método de regulación del caudal en bombas y ventiladores, para ajustar el caudal a lo que realmente se requiere en cada momento, de acuerdo con las necesidades de la central.
- Estrategia C: Instalación de condensadores en diferentes partes de la red, en concreto en los accionamientos y/o en las barras de distribución de los transformadores, para suministrar (o compensar) toda o parte de la potencia reactiva necesaria y disminuir las pérdidas de energía.

Debido a la configuración de los servicios auxiliares y a ciertas limitaciones técnicas, el modelo se ha diseñado teniendo en cuenta las indicaciones dadas por los expertos que participaron en el

Algoritmo 2 Algoritmo WASF-GA

Entrada: Tamaño de la población (N), *CriterioParada*, punto de referencia (\mathbf{q}) y número de vectores de pesos (N_μ).

Salida: Población con los mejores individuos, P .

- 1: Generar $W = N_\mu$ vectores de pesos cuyas direcciones de proyección estén lo mejor equidistribuidas posible.
 - 2: Inicializar P_0 y $h = 0$.
 - 3: **Mientras** no *CriterioParada* **hacer**
 - 4: $Q_h = \text{Selección} - \text{Cruce} - \text{Mutación}(P_h)$.
 - 5: $R_h = P_h \cup Q_h$.
 - 6: $\text{OrdenamientoFuncionLogro}(\mathbf{q}, W, R_h) = \{F_h^i, i = 1, 2, \dots\}$ (fronteras).
 - 7: $P_{h+1} = \emptyset$ y $i = 1$.
 - 8: **Mientras** $|P_{h+1} \cup F_h^i| \leq N$ **hacer**
 - 9: $P_{h+1} = P_{h+1} \cup F_h^i$.
 - 10: $i = i + 1$.
 - 11: **Fin Mientras**
 - 12: Ordenar descendientemente F_h^i por $\text{FuncionLogro}(\mathbf{q}, W, F_h^i)$.
 - 13: Introducir en P_{h+1} los $N - |P_{h+1}|$ primeros individuos de F_h^i .
 - 14: $h = h + 1$.
 - 15: **Fin Mientras**
 - 16: $P = F_{h-1}^1$.
-

estudio, y que se explican a continuación.

Nuestro modelo matemático ha sido diseñado para estudiar la implementación de las estrategias anteriores en un *unifilar* como el que se muestra en la Figura 1. El esquema ante el que nos encontramos dispone de una alimentación para los servicios auxiliares que, en general, consiste en transformadores que reducen de alta tensión (AT) a media tensión (MT), de cuyas barras cuelgan los accionamientos de MT (de 200 kW de potencia o más), y transformadores que reducen de MT a baja tensión (BT), para alimentar los accionamientos de BT (de potencia inferior a 200 kW). Además, cada barra alimenta asimismo a una serie de consumos energéticos, denominados cargas estáticas, como consumos de luz, calefacción, etc... Dichas cargas estáticas no son susceptibles de mejora pero hay que considerarlas en el modelo energético. En nuestro modelo, se asume que un unifilar está compuesto por un único transformador de AT-MT que alimenta varios accionamientos de MT y/o varios transformadores de MT-BT, que alimentan los accionamientos de BT. Si los servicios auxiliares que deseamos estudiar están formados por varios unifilares (esto es, están formados por varios transformadores de AT-MT), bastaría con aplicar el modelo que presentaremos a continuación a cada uno de los unifilares.

Cada accionamiento, tanto bomba como ventilador, desempeña un papel específico dentro de la central, junto con otros accionamientos que funcionan en paralelo desempeñando el mismo rol y con las mismas características técnicas. Es por ello que los accionamientos no funcionan independientemente unos de otros, sino que trabajan conjuntamente por *grupo de accionamientos*. Ahora bien, no todos los accionamientos de un grupo están siempre en funcionamiento, sino que van entrando en operación en función de la carga de operación de la central. Esta configuración de los auxiliares pretende garantizar la estabilidad del sistema, ya que la carga a la que funciona una central varía constantemente en función de la demanda. Además, hay que tener en cuenta que cada grupo cuenta con un accionamiento de repuesto que sólo entra en funcionamiento si alguno de los accionamientos deja de funcionar en algún momento. A efectos de cálculos energéticos,

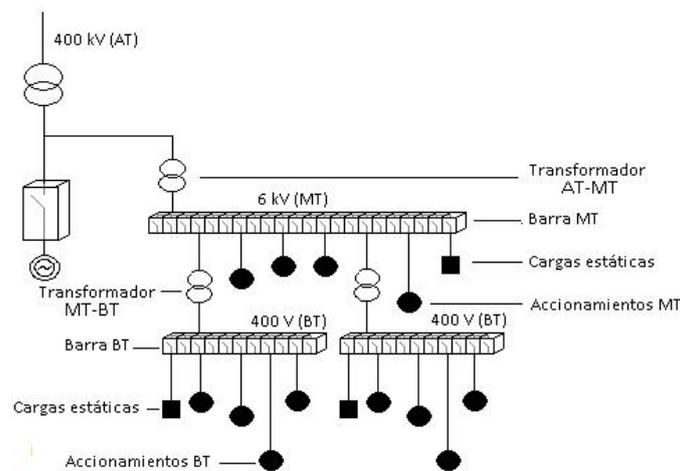


Figura 1. Unifilar objeto de estudio.

el accionamiento de repuesto no se tiene en cuenta, pero sí es necesario considerarlo a la hora de aplicar las estrategias, ya que los accionamientos de cada grupo deben tener siempre las mismas características técnicas.

Como se ha comentado anteriormente, una central eléctrica opera a diferentes niveles de carga en función de las necesidades de electricidad en los diferentes momentos del día. El perfil de operación de la central describe el número de horas anuales que la central está operando a diferentes porcentajes de la carga total. Para calcular la energía consumida por el unifilar, nuestro modelo calcula el consumo de energía suponiendo que la central está trabajando al 100 %, 90 %, 80 %, 70 %, 60 % y 50 % de la carga total, y teniendo en cuenta el número de horas anuales de operación a cada carga.

La estrategia C de instalación de condensadores se puede aplicar en el motor de cualquier accionamiento o en las barras de distribución de cada transformador (para compensar conjuntamente la potencia reactiva de varios accionamientos). Por ello, en el modelo, hemos supuesto que se pueden instalar condensadores 1. individualmente de cada accionamiento, 2. en la barra de distribución de cada transformador, o 3. combinando ambas opciones. Aunque la instalación de condensadores de manera individual es más efectiva porque reduce considerablemente la circulación de corriente por toda la red, es importante tener en cuenta que implica un elevado coste económico y es por ello por lo que normalmente se consideran las otras dos opciones. Asimismo, si se decide instalar condensadores en algún componente del unifilar, no es necesario compensar toda la potencia reactiva requerida sino que se puede compensar sólo parte de la misma. Por último, hay cierta relación entre las estrategias B y C. Si se instala un variador de velocidad en un accionamiento (estrategia B), la potencia reactiva necesaria por el mismo es (casi) nula. En este caso, el modelo matemático descarta automáticamente la estrategia C como una opción de mejora de la eficiencia energética, ya que no habría potencia reactiva que compensar.

Dado que el modelo matemático propuesto se ha diseñado para estudiar la mejora de la eficiencia energética de los auxiliares de cualquier central eléctrica, el modelo no queda totalmente definido hasta que el decisor proporciona cierta información técnica y económica sobre la configuración y funcionamiento de los servicios auxiliares considerados.

3.1. Variables de Decisión

Nuestro problema de optimización considera variables de decisión binarias y continuas que indican la conveniencia de cada estrategia en cada componente susceptible de mejora. Las tres estrategias que hemos considerado se pueden implementar en cualquier accionamiento del unifilar, y además se puede aplicar la estrategia C en las barras de los transformadores, como se ha explicado anteriormente. Para preservar las características técnicas de todos los accionamientos de un mismo grupo, la implementación de las estrategias en los accionamientos se decidirán por grupos, y no por accionamientos individuales. De esta forma, si se decide implementar una estrategia en un grupo, se aplicaría en todos los accionamientos de dicho grupo, incluyendo el de repuesto. Como consecuencia, tendremos tres variables de decisión por cada grupo de accionamientos correspondientes a cada una las estrategias, más una variable de decisión por cada transformador correspondiente a la estrategia C. Es obvio que el número de variables de decisión depende de los elementos que formen el unifilar y, por lo tanto, dicho número puede ser muy elevado.

Sea N_G el número de grupos de accionamientos y N_T el número de transformadores en el unifilar. Para cada $i = 1, \dots, N_G$, las variables de decisión binarias definidas en (6) y en (7) determinan si las estrategias A y B se implementan en los accionamientos de cada grupo, respectivamente:

$$XM_i = \begin{cases} 1 & \text{si los motores de los accionamientos del grupo } i \text{ son de alto rendimiento,} \\ 0 & \text{en otro caso.} \end{cases} \quad (6)$$

$$XV_i = \begin{cases} 1 & \text{si se instalan variadores de velocidad en los accionamientos del grupo } i, \\ 0 & \text{en otro caso.} \end{cases} \quad (7)$$

Es importante aclarar que estas variables de decisión reflejan la situación final de los accionamientos tras aplicar las estrategias que se consideren oportunas, teniendo en cuenta la situación inicial de los mismos con respecto a cada estrategia. Esto es, para decidir si implementar o no las estrategias A y B, el modelo tiene en cuenta si los accionamientos cuentan inicialmente con motores de alto rendimiento y/o si funcionan ya con variadores de velocidad, respectivamente. Tras resolver el problema, se determina realmente en qué accionamientos se aplican las estrategias A y B comparando el valor de las variables de decisión correspondientes con la situación inicial de los accionamientos.

Para cada $i = 1, \dots, N_G$ y $j = 1, \dots, N_T$, las variables de decisión continuas descritas en (8) indican la cantidad de potencia reactiva, en kVAR, que se compensará con condensadores en cada componente:

$$\begin{aligned} XQG_i &= \text{Potencia reactiva a compensar en los accionamientos del grupo } i. \\ XQT_j &= \text{Potencia reactiva a compensar en la barra del transformador } j. \end{aligned} \quad (8)$$

En total, nuestro problema tiene $n = 3 \cdot N_G + N_T$ variables de decisión.

3.2. Restricciones

En relación a las estrategias A y B, para cada $i = 1, \dots, N_G$, las restricciones indicadas en (9) aseguran que la situación final de los accionamientos con respecto a estas estrategias nunca empeora con respecto a su situación inicial:

$$\begin{aligned} M_i^0 &\leq XM_i \leq 1, \\ V_i^0 &\leq XV_i \leq \bar{V}_i, \end{aligned} \quad (9)$$

donde M_i^0 es un variable binaria auxiliar que vale 1 si los motores de los accionamientos del grupo i son inicialmente de alto rendimiento, y 0 en otro caso; V_i^0 es una variable binaria auxiliar que vale 1 si los accionamientos del grupo i tienen instalados inicialmente variadores de velocidad, y 0 en otro caso; y \bar{V}_i es otra variable binaria auxiliar que vale 0 si no es posible instalar variadores de velocidad en los accionamientos del grupo i por limitaciones técnicas, y 1 en otro caso.

Para cada $i = 1, \dots, N_G$ y $j = 1, \dots, N_T$, las restricciones indicadas en (10) controlan que la potencia reactiva compensada en los accionamientos o en las barras de distribución nunca supera la potencia reactiva necesaria:

$$\begin{aligned} 0 \leq XQG_i &\leq \max\{\overline{QG}_i - QG_i^0, 0\}, \\ 0 \leq XQT_j &\leq \max\{\overline{QT}_j - QT_j^0, 0\}, \end{aligned} \quad (10)$$

donde \overline{QG}_i es la potencia reactiva necesaria por los accionamientos del grupo i cuando la central está operando al 100% de carga; QG_i^0 es la potencia reactiva actualmente compensada en los accionamientos del grupo i (en caso de que haya algún condensador ya instalado); \overline{QT}_j es la potencia reactiva requerida por los componentes a los que alimenta la barra del transformador j cuando la central está operando al 100% de carga; y QT_j^0 es la potencia reactiva actualmente compensada en la barra del transformador j (en caso de que haya algún condensador ya instalado).

3.3. Funciones Objetivo

Si $n = 3 \cdot N_G + N_T$ es el número de variables de decisión, nuestro modelo maximiza el ahorro energético anual ($f_1 : \mathbb{R}^n \rightarrow \mathbb{R}$, en MWh), minimiza la inversión económica ($f_2 : \mathbb{R}^n \rightarrow \mathbb{R}$, en millones de €) y maximiza el TIR de la inversión ($f_3 : \mathbb{R}^n \rightarrow \mathbb{R}$, en %).

- Función objetivo f_1 (en MWh). El modelo energético diseñado considera el consumo y las pérdidas de energía, así como la potencia reactiva necesaria de cada componente de los servicios auxiliares. También se han tenido en cuenta diferentes modelos hidráulicos según el método de regulación de caudal empleado en cada bomba y ventilador. Y, como se ha mencionado con anterioridad, el consumo y ahorro de energía se ha calculado anualmente teniendo en cuenta el perfil de operación de la central.

Calcular el ahorro energético alcanzado para unos valores concretos de las variables de decisión no es tarea fácil. Dicho ahorro energético es la diferencia entre el consumo actual de energía y el consumo de energía necesario cuando se llevan a cabo las estrategias indicadas en las variables de decisión, para cada porcentaje de carga a la que opera la central. Debido a la interdependencia del consumo de unos elementos con respecto a otros y a ciertas restricciones técnicas, la mejora de cualquier componente del unifilar mediante alguna estrategia no sólo afecta al consumo de energía de ese elemento, sino que también afecta al consumo del resto de componentes. Así que para calcular el consumo energético tras implementar alguna estrategia, es necesario recalcular los consumos necesarios por todos los elementos del unifilar, desde el más alejado accionamiento hasta el transformador de AT-MT. Este hecho, junto con el uso interno de diversos modelos de ingeniería y el manejo de variables binarias y continuas, hace que el cálculo del ahorro energético resulte complicado y que no se pueda expresar de forma explícita mediante una función matemática. Por ello, esta función objetivo se ha modelado haciendo uso de un simulador de tipo caja negra.

- Función objetivo f_2 (en millones de €). La inversión total es la suma de los costes necesarios para llevar a cabo cada estrategia en cada elemento. Dichos costes se han calculado considerando los precios de los equipos necesarios (nuevos motores, variadores de velocidad, condensadores, etc), costes de instalación y costes de comisión. Téngase en cuenta

que, aunque el accionamiento de repuesto de cada grupo no está en funcionamiento (y, por ello, no se tiene en cuenta en f_1), es necesario considerarlo para calcular la inversión necesaria, puesto que las estrategias han de implementarse en todos los accionamientos del grupo, incluido el de repuesto.

- Función objetivo f_3 (en %). El TIR en un periodo de N años es la tasa de descuento, r , que hace que el valor neto de la inversión inicial (C_0) sea igual al valor presente de los beneficios anuales en dicho periodo (C_l , para $l = 1, \dots, N$). En nuestro modelo, calculamos el TIR a 10 años ($N = 10$). La inversión inicial (en €) viene dada por $C_0 = -f_2 \cdot 10^6$ y el beneficio anual (en €), que es constante en todos los años, es igual al ahorro económico que supone el ahorro energético calculado con f_1 . Se ha supuesto que el precio de producción de la energía es 0.05 €/kWh ³, con lo que tenemos $C_l = 0,05 \cdot f_1 \cdot 10^3$ para todo $l = 1, \dots, 10$. De esta forma, $f_3 = 100 \cdot r$ se calcula de forma implícita a partir de la siguiente ecuación, que se resuelve mediante el método de bisección⁴ en nuestro modelo:

$$C_0 + \sum_{l=1}^N \frac{C_l}{(1+r)^l} = 0 \iff -f_2 \cdot 10^6 + \sum_{l=1}^{10} \frac{0,05 \cdot f_1 \cdot 10^3}{(1+r)^l} = 0. \quad (11)$$

Finalmente, si definimos el vector de variables de decisión como:

$$\mathbf{X} = \{XM_1, \dots, XM_{N_G}, XV_1, \dots, XV_{N_G}, XQG_1, \dots, XQG_{N_G}, XQT_1, \dots, XQT_{N_T}\},$$

y consideramos que D es el subconjunto de \mathbb{R}^n formado por los vectores de decisión que verifican las restricciones dadas en (9) y (10), el problema de optimización multiobjetivo considerado queda definido por:

$$\begin{aligned} & \text{minimizar} && -f_1(\mathbf{X}), \\ & \text{minimizar} && f_2(\mathbf{X}), \\ & \text{minimizar} && -f_3(\mathbf{X}), \\ & \text{sujeto a} && \mathbf{X} \in D. \end{aligned} \quad (12)$$

Como se ha mencionado anteriormente, resulta necesario un simulador de tipo caja negra para calcular el valor de las funciones objetivo debido a la complejidad de la modelización del problema. Para ello, se ha implementado una subrutina de evaluación en el lenguaje C# basada en modelos de ingeniería que simulan el consumo energético de los servicios auxiliares. Dicha subrutina tiene en cuenta todas las interconexiones existentes entre los diferentes elementos y las posibles mejoras introducidas en el modelo por las variables de decisión. De esta manera, cada vez que el software diseñado para la resolución del problema necesita evaluar las funciones objetivo en tiempo de ejecución, se hace una llamada interna a esta subrutina de evaluación usando los valores de las variables de decisión correspondientes. El software desarrollado está disponible bajo petición y no se describe en mayor profundidad por limitación de espacio.

4. Resolución del Problema de Optimización Multiobjetivo

En esta sección, se describe el proceso de resolución diseñado para resolver el problema que nos ocupa y se proporcionan los resultados obtenidos en un caso de estudio concreto.

³Precio aproximado proporcionado por Endesa Generación S.A. en 2010.

⁴El método de la bisección es un algoritmo de búsqueda de raíces o soluciones de ecuaciones de una variable basado en el Teorema del Valor Medio.

4.1. *Proceso de Resolución*

Para resolver el problema (12) junto con un decisor, hemos diseñado un proceso interactivo cuyo objetivo es permitir que el decisor conozca las características principales del problema y entienda qué tipo de soluciones Pareto óptimas son posibles, y que sea capaz de definir sus preferencias para que finalmente pueda encontrar una solución que se ajuste a sus necesidades. Dicho proceso está compuesto por una fase inicial (no interactiva) y una fase interactiva:

Fase inicial

Inicialmente, el decisor ha de introducir la información técnica y económica que describe el unifilar bajo estudio y que define completamente el problema (12) a resolver. Tras ello, el objetivo principal de esta fase es analizar y estudiar el frente óptimo de Pareto correspondiente. Para ello, una vez que el problema (12) se ha definido completamente, se obtiene una aproximación del conjunto de soluciones Pareto óptimas ejecutando NSGA-II, lo que nos permitirá conocer el grado de conflicto existente entre los tres criterios considerados. Hemos de decir que se ha empleado un algoritmo evolutivo porque las técnicas de optimización tradicionales MCDM no son adecuadas al manejar funciones objetivo discontinuas y de tipo caja negra, y variables de decisión continuas y binarias.

Fase interactiva

Esta fase está destinada a definir e introducir las preferencias del decisor en el proceso de resolución para converger hacia una solución final. Esta fase consta de dos etapas:

1. *Definición de preferencias.* Tras analizar la aproximación del frente óptimo de Pareto del problema, es necesario introducir cierta información preferencial en el proceso que ayude al decisor a determinar su región de interés, de donde seleccionará la solución final del problema. En nuestro modelo, la información preferencial que se le solicita es un punto de referencia, con el que el decisor proporciona valores que le gustaría alcanzar en cada función objetivo. Sin embargo, inicialmente, es complicado que el decisor sea capaz de dar un punto de referencia a partir del cual se generen soluciones que sean de su interés, esto es, que realmente defina su región de interés. Debido a esta necesidad, se ha diseñado un proceso que permite analizar qué soluciones se podrían obtener a partir de diferentes puntos de referencia antes de elegir el definitivo.

El proceso propuesto está basado en la minimización de la función escalarizada de logro de dos pendientes dada en (3) sobre el conjunto de soluciones no dominadas obtenidas con NSGA-II, que denotaremos por P . Inicialmente, el decisor proporciona un punto de referencia en base a la información obtenida en la fase inicial. Con ese punto de referencia, se minimiza (3) sobre P para obtener la solución de dicho conjunto que mejor se ajusta al punto de referencia. Se ha decidido usar esta función de logro porque permite emplear diferentes vectores de pesos para puntos de referencia alcanzables e inalcanzables y, en este proceso, no se conoce a priori de qué tipo será el punto de referencia proporcionado por el decisor. Los vectores de pesos empleados en la función (3) se calculan según la expresión (5), para lo que se le pide al decisor que proporcione la información preferencial descrita en la Sección 2.

Tras analizar los valores de las funciones objetivo en la solución obtenida, el decisor puede decidir continuar con el punto de referencia dado o no. En caso negativo, hay dos opciones: a) puede analizar el mismo punto de referencia en mayor profundidad, para lo que proporcionará nueva información preferencial que permita calcular nuevos vectores de pesos, o

b) puede estudiar un nuevo punto de referencia, para lo que proporcionará nuevos valores deseables para cada objetivo.

Al minimizar (3) sobre el conjunto P usando los vectores de pesos obtenidos con (5), el decisor tiene una idea de los valores de las funciones objetivo que se pueden obtener a partir del punto de referencia dado. Hay que aclarar que el objetivo de esta fase es simplemente ayudar y guiar al decisor para definir un punto de referencia que se corresponda con sus intereses, no resolver el problema en sí. Además, dado que la función (3) se minimiza sobre el conjunto finito P , el coste computacional asociado a esta fase es inapreciable, pese a su gran valor informativo desde el punto de vista del decisor.

2. **Aproximación de la región de interés.** Para ello, resolvemos el problema (12) con el algoritmo evolutivo basado en preferencias WASF-GA usando el punto de referencia seleccionado en la etapa anterior. Este método proporcionará al decisor un número reducido de soluciones no dominadas que aproximarán la región de interés definida por dicho punto de referencia. Es más, en este momento, el decisor ha de indicar el número de soluciones que desea examinar en la región de interés para ajustar el valor de N_μ en WASF-GA. Si el decisor encuentra alguna solución que le satisfaga suficientemente entre las soluciones generadas por WASF-GA, dicha solución es la solución final del problema. En caso contrario, puede afinar la búsqueda ajustando el punto de referencia en base a la información proporcionada, tras lo que se ejecuta nuevamente WASF-GA. Este proceso repetitivo continua hasta que el decisor encuentra una solución final.

Para resolver el problema, se han implementado los algoritmos NSGA-II y WASF-GA y se ha codificado la minimización de la función (3) en el lenguaje C#. En la Tabla 1 se puede ver la complejidad computacional de cada fase, en la que N_1 y N_2 denotan el tamaño de población empleado en NSGA-II y WASF-GA, respectivamente. Con respecto al coste computacional que requiere la subrutina de evaluación, no es posible calcularlo de manera exacta debido a que se trata de un simulador de tipo caja negra. Lo único que podemos asegurar es que depende del número de elementos del unifilar bajo estudio, ya que el número de variables de decisión es $n = 3 \cdot N_G + N_T$, lo que implica que el coste computacional asociado a la subrutina de evaluación aumenta con el número de grupos y de transformadores que componen el unifilar.

Tabla 1. Complejidad computacional

| <i>Proceso de resolución</i> | Metodología | Coste computacional |
|---|--|------------------------------|
| Fase inicial | NSGA-II | $O(3 \cdot N_1^2)$ |
| Fase interactiva - definición de preferencias | Minimización de la función (3) sobre P | $O(N_1 \cdot \log N_1)$ |
| Fase interactiva - aproximación de la región de interés | WASF-GA | $O(3 \cdot N_2 \cdot N_\mu)$ |

4.2. Resultados Obtenidos en un Caso de Estudio

El caso de estudio que hemos considerado está basado en el unifilar formado por los elementos descritos en la Tabla 2. En este caso, tenemos un transformador de AT-MT, dos transformadores de MT-BT, ocho grupos de accionamientos de MT y dos grupos de BT, cada uno de ellos con varios accionamientos. Estos servicios auxiliares corresponden a una central eléctrica de 1100 MW de potencia.

A continuación, se describen y analizan los resultados obtenidos al resolver el problema de optimización multiobjetivo asociado al caso de estudio anterior, donde un ingeniero de Endesa

Tabla 2. Unifilar del caso de estudio.

| Nombre | Descripción |
|----------|--|
| T_1 | Transformador de AT-MT |
| T_2 | Transformador de MT-BT |
| T_3 | Transformador de MT-BT |
| G_1 | Grupo de MT de ventiladores de aire primario (2 accionamientos) |
| G_2 | Grupo de MT de bombas de extracción de condensado (2 accionamientos) |
| G_3 | Grupo de MT de bombas de re-circulación (3 accionamientos) |
| G_4 | Grupo de MT de bombas de agua de circulación (1 accionamiento) |
| G_5 | Grupo de MT de bombas de agua de circulación (1 accionamiento) |
| G_6 | Grupo de MT de molinos de carbón (5 accionamientos) |
| G_7 | Grupo de MT de ventiladores de tiro inducido (2 accionamientos) |
| G_8 | Grupo de MT de ventiladores de tiro forzado (2 accionamientos) |
| G_9 | Grupo de BT de bombas de agua de servicio (2 accionamientos) |
| G_{10} | Grupo de BT de bombas de agua de refrigeración (2 accionamientos) |

Generación S.A. desempeñó el papel de decisor.

Fase inicial

Inicialmente se configuró el problema (12) correspondiente a nuestro caso de estudio, en el que se definieron 33 variables de decisión, 13 continuas y 20 binarias. Los resultados obtenidos por NSGA-II⁵ pueden verse en la Figura 2, donde se muestra gráficamente la aproximación del frente óptimo de Pareto y una comparativa dos a dos de los valores obtenidos para las funciones objetivo. Los valores mínimos y máximos alcanzados por cada función objetivo en las soluciones generadas por NSGA-II se recogen en la Tabla 3.

Tabla 3. Rangos de las funciones objetivo obtenidos por NSGA-II.

| Función objetivo | Mínimo | Máximo |
|-----------------------|--------|----------|
| f_1 (MWh) | 408.49 | 47526.37 |
| f_2 (millones de €) | 0.46 | 9.29 |
| f_3 (%) | 22.13 | 99.99 |

En la Figura 2, se puede observar que el frente óptimo de Pareto está formado por varios subconjuntos discontinuos. Por un lado, estas discontinuidades son debidas a los saltos que experimenta el ahorro energético (f_1) cada vez que una variable binaria toma el valor 1, ya que ello significa que el ahorro de energía aumenta bruscamente en cierta cantidad. Por otro lado, debido a los costes de comisión que hemos tenido en cuenta para calcular el coste de cada estrategia, la función objetivo f_2 presenta discontinuidades cada vez que alguna variable continua pasa de 0 a un valor positivo. Las variables de decisión continuas indican la cantidad de potencia reactiva a compensar, con lo cual una pequeña variación de una de estas variables, hace que la inversión varíe de forma discontinua debido a las comisiones que se cargan inicialmente.

Con respecto a la comparativa dos a dos de las funciones objetivo de la Figura 2, al comparar f_1 frente a f_2 , se puede ver que la inversión aumenta a medida que se incrementa el ahorro energético, e incluso la tasa de crecimiento es mayor para los ahorros energéticos más elevados.

⁵Los parámetros empleados en la ejecución de NSGA-II son: tamaño de población 2000 y 650 generaciones; los operadores de cruce empleados han sido Simulated Binary Crossover (SBX) para las variables continuas y cruce binario para las variables binarias (Deb (2001)), con probabilidad de cruce 0.9 e índice de distribución 25; los operadores de mutación utilizados fueron distribución polinomial para las variables continuas y mutación binaria para las variables binarias (Deb (2001)), con probabilidad de cruce $1/n$, siendo n el número de variables, e índice de distribución 2.

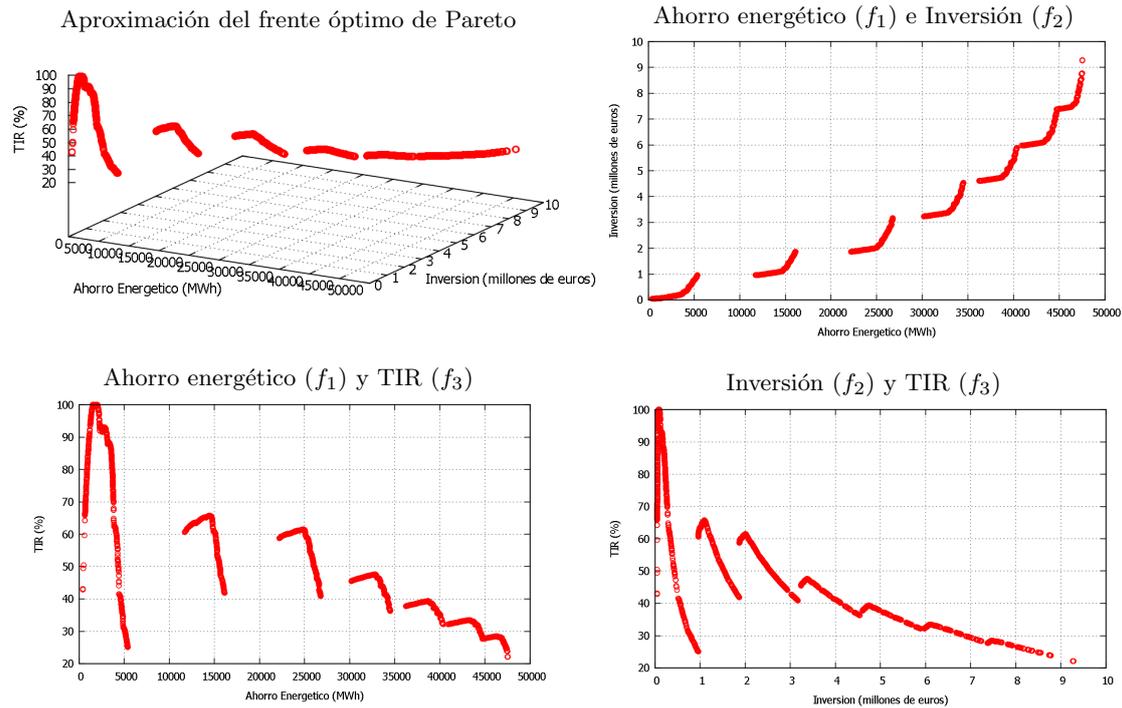


Figura 2. Soluciones obtenidas con NSGA-II.

Esto es lógico ya que, para obtener un mayor ahorro energético, es necesario hacer una inversión mayor. Respecto f_1 frente a f_3 , se puede observar que el TIR aumenta bruscamente inicialmente para los ahorros energéticos más bajos, mientras que disminuye poco a poco hasta llegar al máximo ahorro energético. Podríamos decir que, desde una perspectiva global, el TIR disminuye a medida que aumenta el ahorro energético. Dado que ahorro energético e inversión económica están en relación directa, la relación existente entre inversión y TIR es similar a la descrita entre ahorro energético y TIR.

Fase interactiva

En esta fase es donde realmente se interactúa con el decisor para hallar la solución final del problema:

1. **Definición de preferencias.** En cuanto a la selección del punto de referencia, el decisor decidió tantear varios puntos antes de elegir aquél que mejor expresaba sus preferencias. Teniendo en cuenta los rangos obtenidos para las tres funciones objetivo, el decisor comenzó analizando un punto de referencia con el que deseaba alcanzar un ahorro energético muy elevado para una inversión pequeña, pero los resultados obtenidos no fueron satisfactorios. Posteriormente, se analizaron algunos puntos de referencia más, en los que el decisor fue afinando mejor los valores deseados para cada función objetivo, hasta que finalmente encontró un punto de referencia suficientemente bueno. En esta fase, la función de logro de dos pendientes resultó de gran utilidad para estudiar los valores que se podían alcanzar desde cada punto de referencia que el decisor analizó. Finalmente, el decisor eligió el punto de referencia $\mathbf{q} = (30000,00, 4,00, 60,00)$, el cual se puede ver en el espacio de objetivos representado en la Figura 3. En esta gráfica, se ha marcado con una línea curva discontinua la región de interés que se ha aproximado en la etapa siguiente con el algoritmo WASF-

GA. En dicha región, se pueden alcanzar soluciones con valores del ahorro energético entre 20 – 40 MWh, de la inversión entre 2 – 4 millones de €, y del TIR entre el 40 – 60 %.

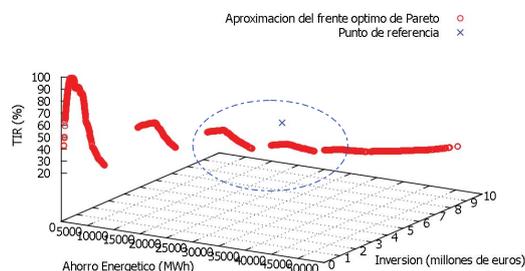


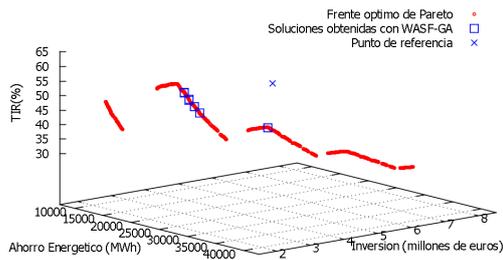
Figura 3. Punto de referencia seleccionado por el decisor.

2. *Aproximación de la región de interés.* De acuerdo con el punto de referencia seleccionado, se ejecutó WASF-GA⁶ para generar un conjunto con 10 soluciones en la región de interés ($N_\mu = 10$), que fue el número de soluciones que el decisor deseaba analizar. En nuestro caso de estudio, se necesitaron tres ejecuciones del algoritmo WASF-GA hasta que el decisor encontró su solución final. A continuación, denotaremos por h el número de iteración actual, \mathbf{q}^h será el punto de referencia empleado en la iteración h y \mathbf{z}^h será la solución seleccionada por el decisor en la iteración h entre las soluciones generadas por WASF-GA.

En la primera iteración, fijamos $h = 1$ y $\mathbf{q}^1 = \mathbf{q} = (30000,00, 4,00, 60,00)$. La Figura 4 muestra una representación en el espacio de objetivos de las soluciones generadas por WASF-GA para \mathbf{q}^1 y una tabla con los valores correspondientes a los vectores objetivo asociados a dichas soluciones. Se puede observar que ninguna solución necesita una inversión superior al valor deseado (4 millones de €) y, aunque hay algunas soluciones con valores del TIR próximos al 60 %, ninguna alcanza este valor ni lo mejora. Además, se han obtenido dos subconjuntos de soluciones claramente diferenciados: las soluciones que quedan más a la izquierda (soluciones 1, 2, 3, 4, 5, 7 y 8), que presentan valores altos del TIR, requieren una inversión más baja y, por consiguiente, alcanzan ahorros energéticos más pequeños; y las soluciones más a la derecha (soluciones 6, 9 y 10), que consiguen mayores ahorros energéticos y requieren un sacrificio en el TIR y la inversión, los cuales alcanzan peores valores. Tras este análisis, el decisor decidió dar más importancia al ahorro energético, por lo que eligió la solución que obtuvo el mayor valor para f_1 y seleccionó $\mathbf{z}^1 = (32812,55, 3,39, 47,44)$.

Sin embargo, observó que era posible obtener soluciones con ahorros energéticos más elevados en la zona del frente óptimo de Pareto en la que se encontraba la solución \mathbf{z}^1 . Obviamente, aumentar el ahorro energético supondría un sacrificio en la inversión y en el TIR, por lo que decidió investigar qué soluciones y qué tipo de trade-offs entre las funciones objetivo se podrían obtener en esta zona. Para ello, se llevó a cabo una nueva iteración ($h = 2$), en la que el decisor proporcionó el siguiente nuevo punto de referencia $\mathbf{q}^2 = (35000,00, 4,00, 47,00)$, más próximo a la zona deseada. Las soluciones obtenidas por WASF-GA en esta segunda iteración se pueden ver en la Figura 5. Puede observarse que,

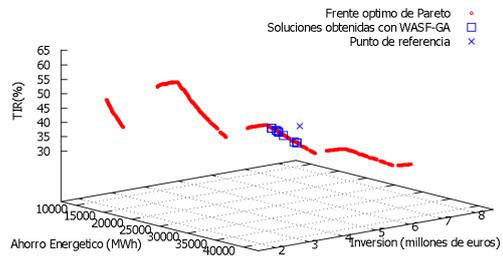
⁶En WASF-GA, se han usado los mismos parámetros que en NSGA-II, con tamaño de población 200 y 300 generaciones.



| Sol. | f_1 (MWh) | f_2 (mill. de €) | f_3 (%) |
|------|----------------|-----------------------|--------------|
| 1 | 25395.35 | 2.15 | 58.34 |
| 2 | 25560.07 | 2.27 | 55.66 |
| 3 | 25371.73 | 2.15 | 58.49 |
| 4 | 25555.98 | 2.26 | 55.97 |
| 5 | 25795.61 | 2.39 | 53.23 |
| 6 | 32812.55 | 3.39 | 47.44 |
| 7 | 25950.13 | 2.51 | 50.83 |
| 8 | 25792.67 | 2.38 | 53.34 |
| 9 | 32812.55 | 3.39 | 47.44 |
| 10 | 32812.55 | 3.39 | 47.44 |

Figura 4. Soluciones obtenidas por WASF-GA para q^1 .

aunque ninguna solución alcanza el ahorro energético deseado (35000.00 MWh), todas ellas han mejorado los valores de los ahorros energéticos obtenidos en la iteración anterior. Además, como era de esperar, todas las soluciones alcanzan valores del TIR más bajos (aunque siguen siendo muy altos desde el punto de vista económico) y, en general, las inversiones económicas necesarias se han incrementado con respecto a las de la anterior iteración. Incluso las soluciones 9 y 10 requieren una inversión superior a los 4 millones de €, aunque a cambio ambas soluciones alcanzan los mayores ahorros de energía. En base a estas información, y teniendo en cuenta que los valores del TIR indicaron que todas las soluciones eran muy rentables económicamente hablando, el decisor prefirió la solución que obtuvo el mayor ahorro energético sin sobrepasar los 4 millones de €, por lo que seleccionó $z^2 = (33961,83, 4,00, 41,11)$.



| Sol. | f_1 (MWh) | f_2 (mill. de €) | f_3 (%) |
|------|----------------|-----------------------|--------------|
| 1 | 33021.98 | 3.49 | 46.29 |
| 2 | 33389.44 | 3.61 | 45.16 |
| 3 | 33003.20 | 3.48 | 46.35 |
| 4 | 33324.21 | 3.57 | 45.55 |
| 5 | 33430.26 | 3.63 | 44.86 |
| 6 | 33961.83 | 4.00 | 41.11 |
| 7 | 33562.31 | 3.75 | 43.61 |
| 8 | 33430.26 | 3.63 | 44.86 |
| 9 | 34126.43 | 4.07 | 40.54 |
| 10 | 34101.79 | 4.06 | 40.56 |

Figura 5. Soluciones obtenidas por WASF-GA para q^2 .

Cuando se analizaron los valores de las variables de decisión en la solución z^2 , observamos que había ciertas variables continuas que tomaban valores muy bajos. Dado que las variables continuas indican la potencia reactiva a compensar en los elementos correspondientes, el decisor indicó que no tenía sentido instalar condensadores para compensar tan poca potencia reactiva. Inicialmente, podríamos haber incluido en el modelo una restricción para controlar que, en caso de aplicar la estrategia C, se compensara siempre una mínima cantidad de potencia reactiva, pero el decisor no indicó esta restricción al inicio. Esta observación nos condujo a pensar que estas variables de decisión podrían estar elevando la inversión en exceso, a cambio de una mejora del ahorro energético muy reducida, lo que además estaría disminuyendo el TIR de la inversión. Por ello, se decidió hacer una última ejecución de WASF-GA para analizar qué soluciones se podrían obtener si fijáramos z^2 como punto de referencia y, al mismo tiempo, forzáramos a que las variables

de decisión mencionadas anteriormente valieran 0. Para ello, fijamos $h = 3$, $\mathbf{q}^3 = \mathbf{z}^2 = (33961,83, 4,00, 41,11)$ y acotamos dichas variables de decisión superiormente por 0. Las soluciones obtenidas por WASF-GA se pueden ver en la Figura 6. Es fácil observar que todas las soluciones obtenidas en esta ejecución dominan al punto de referencia \mathbf{q}^3 . Dado que ninguna solución necesitaba una inversión superior a 4 millones de €, el decisor prefirió la solución con el mayor ahorro energético, así que seleccionó $\mathbf{z}^3 = (34091,29, 3,99, 41,36)$. En comparación con \mathbf{z}^2 , la solución \mathbf{z}^3 ahorra 129.46 MWh más y necesita 6375.5 € menos, así que \mathbf{z}^3 representa una solución más rentable que \mathbf{z}^2 .

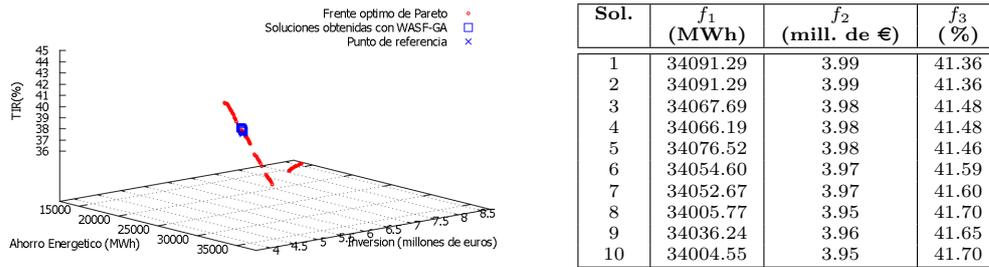


Figura 6. Soluciones obtenidas por WASF-GA para \mathbf{q}^3 .

En la solución final \mathbf{z}^3 se alcanzó un ahorro energético de 34091.29 MWh, para lo que era necesaria una inversión de 4 millones de €, y dicha inversión alcanzaba un TIR a 10 años del 41.36%. Para obtener estos valores, las estrategias a implementar serían las siguientes: los motores de los accionamientos de los grupos G_1 , G_6 , G_9 y G_{10} deben sustituirse por motores de alto rendimiento (estrategia A), y han de instalarse variadores de velocidad en los accionamientos de los grupos G_2 , G_4 , G_5 , G_9 y G_{10} (estrategia B). Además, se deben instalar condensadores para compensar 20200 kVAR en la barra del transformador T_1 , 450 kVAR en las de los transformadores T_2 y T_3 , respectivamente, y 480 kVAR en los accionamientos del grupo G_1 (estrategia C). La Figura 7 muestra cómo quedaría el unifilar del caso de estudio tras aplicar dichas estrategias de mejora, donde los grupos de accionamientos en los que se sustituyen los motores se han representado en verde (estrategia A), aquellos en los que han de instalarse variadores de velocidad se han resaltado en rojo (estrategia B) y se ha indicado en azul las cantidades de potencia reactiva que han de compensarse con condensadores (estrategia C).

5. Conclusiones

En este trabajo, hemos formulado el problema de optimización multiobjetivo asociado a la mejora de la eficiencia de los servicios auxiliares de centrales eléctricas, que son elementos necesarios para el propio funcionamiento de la central. Se han considerado tres estrategias para mejorar la eficiencia energética de los servicios auxiliares: (a) sustitución de los motores actuales por otros de alto rendimiento; (b) instalación de variadores de velocidad; (c) compensación de potencia reactiva mediante la instalación de condensadores. En el problema de optimización multiobjetivo propuesto, se pretende determinar qué estrategias han de implementarse en los servicios auxiliares para maximizar el ahorro energético, minimizar la inversión económica necesaria y maximizar el TIR (Tasa Interna de Retorno) de la inversión.

El modelo matemático diseñado considera variables de decisión de naturaleza binaria y continua para determinar la implementación de las estrategias en los elementos susceptibles de mejora. La

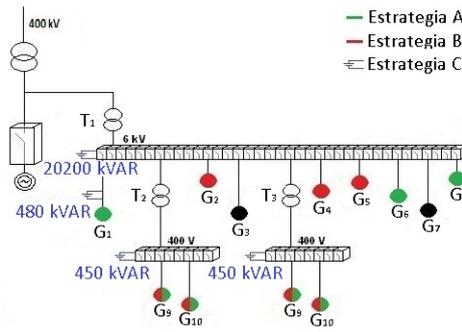


Figura 7. Unifilar del caso de estudio - aplicación práctica de la solución \mathbf{z}^3 .

modelización matemática que hemos llevado a cabo se ha diseñado de tal forma que el modelo puede emplearse para estudiar la mejora de los servicios auxiliares de cualquier central eléctrica. Ello, unido a la interdependencia energética de unos elementos con respecto a otros, ha hecho que algunas de nuestras funciones objetivo no puedan expresarse de forma explícita y haya resultado necesario emplear un simulador de tipo caja negra para la evaluación. Además, el número de variables depende de la configuración de los auxiliares que se pretendan analizar, por lo que podemos encontrarnos ante un problema con un elevado número de variables de decisión.

En este trabajo, hemos considerado un caso de estudio concreto y hemos resuelto el problema multiobjetivo asociado mediante un proceso de resolución que combina diferentes técnicas de optimización multiobjetivo. El principal objetivo ha sido proporcionar al decisor información que le permita conocer la relación y el conflicto existente entre las funciones objetivo, y ajustar posteriormente la búsqueda de soluciones a sus preferencias para finalmente encontrar la solución final del problema. En la fase inicial, se aproximó el frente óptimo de Pareto para analizar los trade-offs entre los objetivos. Debido a las características de nuestro problema (funciones objetivo discontinuas y de tipo caja negra, y variables de decisión continuas y binarias) descartamos el uso de los métodos clásicos de optimización y se empleó el algoritmo evolutivo NSGA-II (Deb et al. (2002)). Del conjunto de soluciones obtenidas por el NSGA-II, pudimos concluir que las soluciones en las que se alcanzaban los mayores ahorros energéticos, requerían inversiones más elevadas, y viceversa. En general, el TIR alcanzó valores bastante altos en todas las soluciones, lo cual demuestra la elevada rentabilidad de cualquiera de las soluciones. Sin embargo, los valores del TIR más elevados se obtuvieron en las soluciones que requerían menor inversión pero, obviamente, el ahorro energético alcanzado en estos casos era menor, lo que hacía que estas soluciones no resultaran tan atractivas desde el punto de vista energético. Pese a que las soluciones con altos ahorros energéticos alcanzaban valores del TIR más pequeños, dichos valores continuaban siendo muy interesantes desde el punto de vista económico.

Dado que el NSGA-II proporcionó un elevado número de soluciones y era complicado que el decisor pudiera analizar y comparar todas ellas en busca de la solución final, decidimos llevar a cabo una fase interactiva. En esta fase, se incorporó información preferencial en el proceso de resolución, la cual se expresó a través de un punto de referencia que contenía valores deseables para las funciones objetivo, y se aproximó la región de interés asociada a las preferencias expresadas. Para determinar un punto de referencia adecuado, se diseñó un proceso basado en la minimización de la función escalarizada de logro de dos pendientes (Luque et al. (2012)) sobre el conjunto de soluciones generado por el NSGA-II. Este paso permitió al decisor analizar qué tipo de soluciones que se podían alcanzar para cada punto de referencia analizado antes de seleccionar uno definitivo.

Posteriormente, se ejecutó el algoritmo evolutivo basado en preferencias WASF-GA (Ruiz et al. (2015)) para aproximar la región definida por el punto de referencia seleccionado. Se llevaron a cabo varias ejecuciones de WASF-GA antes de obtener la solución final, a través de las cuales el decisor fue analizando las soluciones obtenidas y afinando poco a poco la búsqueda hasta converger en una solución suficientemente buena. A lo largo de esta parte, el decisor se mostró más interesado en las soluciones que alcanzaron mejores ahorros energéticos, a costa de obtener valores del TIR algo más pequeños y necesitar mayores inversiones, siempre y cuando dichas inversiones no superaban la máxima inversión deseable.

Desde el punto de vista metodológico, esta aplicación nos ha permitido demostrar la utilidad de los algoritmos evolutivos para resolver problemas reales complejos. Asimismo, los resultados obtenidos por el algoritmo WASF-GA han dejado claro que la inclusión de preferencias en los procesos de decisión resulta de gran relevancia para encontrar la solución que mejor satisface las necesidades y preferencias del decisor. Además, la función de logro de dos pendientes resultó de gran utilidad para estudiar los valores que se podrían alcanzar desde diferentes puntos de referencia antes de ejecutar WASF-GA. Cabe destacar que la combinación de diferentes técnicas para resolver nuestro problema ha sido decisiva para obtener un solución final satisfactoria para el decisor. Dicha combinación proporciona muchas ventajas frente al uso de una única metodología, dado que cada técnica utilizada se ha empleado para fines completamente distintos y ha proporcionado información muy valiosa para entender el problema en su conjunto.

Desde el punto de vista práctico, los resultados obtenidos ponen de manifiesto que la implementación de las estrategias consideradas para mejorar la eficiencia de los servicios auxiliares puede dar lugar a importantes ahorros energéticos, y que las inversiones requeridas son, en general, muy rentables desde el punto de vista económico, ya que los valores del TIR alcanzados son realmente muy altos. De hecho, como conclusión, se puede decir que este tipo de problemas no se pueden analizar atendiendo únicamente a criterios energéticos. Es necesario hacer un análisis económico en profundidad para determinar la opción más rentable, teniendo en cuenta las necesidades energéticas y económicas del decisor. Realmente, los dos criterios económicos considerados han desempeñado un papel muy importante en el problema, ya que han ayudado a distinguir las diferentes soluciones en función de las diferentes rentabilidades económicas que se podían alcanzar.

Agradecimientos

Esta investigación ha sido financiada parcialmente por el contrato I+D+i “*Aumento de la eficiencia de las centrales eléctricas, mediante la optimización del suministro energético de los sistemas auxiliares (OSA)*” con la empresa Endesa Generación S.A. También me gustaría agradecer la financiación recibida por parte de la Junta de Andalucía (grupo PAI SEJ-445 y proyecto P09-FQM-05001) y por parte del Gobierno de España (proyecto MTM2010-14992). Finalmente, me gustaría dar las gracias al Dr. Mariano Luque Gallego, al Dr. José Manuel Cabello González y al Dr. Francisco Ruiz de la Rúa por sus comentarios y sugerencias en la elaboración de este trabajo.

Referencias bibliográficas

1. A.L. Orillé Fernández. *Centrales Eléctricas, volumen II: Generadores, servicios auxiliares, estaciones transformadoras, fenómenos y técnicas de ruptura en los circuitos eléctricos*. Ediciones UPC, Barcelona, 1993.
2. G. Min and D.M. Rowe. Conversion efficiency of thermoelectric combustion systems. *IEEE Transactions on Energy Conversion*, 22(2):528–534, 2007.

3. ABB PSP Marketing North America ABB Ltd. Switzerland. *Power Generation. Energy Efficiency Design of Auxiliary Systems in Fossil-Fuel Power Plants*. ABB, 2009.
4. Z. Huang and R.M. Edwards. Power generation efficiency improvement through auxiliary system modifications. *IEEE Transactions on Energy Conversion*, 18(4):525–529, 2003.
5. V. Belton, J. Branke, P. Eskelinen, S. Greco, J. Molina, F. Ruiz, and R. Slowinski. Interactive multiobjective optimization from a learning perspective. In J. Branke, K. Deb, K. Miettinen, and R. Slowinski, editors, *Multiobjective Optimization. Interactive and Evolutionary Approaches*, volume 5252 of *Lecture Notes in Computer Science*, pages 405–433. Springer, 2008.
6. K. Deb. *Multi-objective Optimization using Evolutionary Algorithms*. Wiley, Chichester, 2001.
7. C.A.C. Coello, G.B. Lamont, and D.A.V. Veldhuizen. *Evolutionary Algorithms for Solving Multi-Objective Problems. Second Edition*. Springer, New York, 2007.
8. A. Zhou, B.-Y. Qu, H. Li, S.-Z. Zhao, P.N. Suganthan, and Q. Zhang. Multiobjective evolutionary algorithms: A survey of the state of the art. *Swarm and Evolutionary Computation*, 1(1):32–49, 2011.
9. K. Deb, A. Pratap, S. Agarwal, and T. Meyarivan. A fast and elitist multiobjective genetic algorithm: NSGA-II. *IEEE Transactions on Evolutionary Computation*, 6(2):182–197, 2002.
10. M. Luque, K. Miettinen, A.B. Ruiz, and F. Ruiz. A two-slope achievement scalarizing function for interactive multiobjective optimization. *Computers & Operations Research*, 39(7):1673–1681, 2012.
11. A.B. Ruiz, R. Saborido, and M. Luque. A preference-based evolutionary algorithm for multiobjective optimization: The weighting achievement scalarizing function genetic algorithm. *Journal of Global Optimization*, 62(1):101–129, 2015.
12. European Commission. Climate Action. Energy for a Changing World. <http://ec.europa.eu/clima/>, June 2012.
13. J.M. Cabello, M. Luque, F. Miguel, A.B. Ruiz, and F. Ruiz. A multiobjective interactive approach to determine the optimal electricity mix in Andalucía (Spain). *TOP*, 22(1):109–127, 2014.
14. D. Diakoulaki, C.H. Antunes, and A.G. Martins. MCDA and energy planning. In *Multiple Criteria Decision Analysis: State of the Art Surveys*, volume 78 of *International Series in Operations Research & Management Science*, pages 859–890. Springer New York, 2005.
15. E. Laken. Use of multicriteria decision analysis methods for energy planning problems. *Renewable and Sustainable Energy Reviews*, 11(7):1584 – 1595, 2007.
16. P. Zhou, B.W. Ang, and K.L. Poh. Decision analysis in energy and environmental modeling: An update. *Energy*, 31(14):2604 – 2622, 2006.
17. K. Miettinen. *Nonlinear Multiobjective Optimization*. Kluwer Academic Publishers, Boston, 1999.
18. J.M. Cabello, J.M. Cejudo, M. Luque, F. Ruiz, K. Deb, and R. Tewari. Optimization of the size of a solar thermal electricity plant by means of genetic algorithms. *Renewable Energy*, 36(11):3146 – 3153, 2011.
19. K. Deb, F. Ruiz, M. Luque, R. Tewari, J.M. Cabello, and J.M. Cejudo. On the sizing of a solar thermal electricity plant for multiple objectives using evolutionary optimization. *Applied Soft Computing Journal*, 12(10):3300–3311, 2012.
20. P. Ahmadi, I. Dincer, and M.A. Rosen. Exergy, exergoeconomic and environmental analyses and evolutionary algorithm based multi-objective optimization of combined cycle power plants. *Energy*, 36(10):5886–5898, 2011.
21. J. Dipama, A. Teyssedou, F. Aubè, and L. Lizon-A-Lugrin. A grid based multi-objective evolutionary algorithm for the optimization of power plants. *Applied Thermal Engineering*, 30(8-9):807–816, 2010.

22. P. Di Barba and M.E. Mognaschi. Industrial design with multiple criteria: Shape optimization of a permanent-magnet generator. *IEEE Transactions on Magnetics*, 45(3):1482–1485, 2009.
23. J.L.C. Meza, M.B. Yildirim, and A.S.M. Masud. A multiobjective evolutionary programming algorithm and its applications to power generation expansion planning. *IEEE Transactions on Systems, Man and Cybernetics – Part A: Systems and Humans*, 39(5):1086–1096, 2009.
24. A. Toffolo and A. Lazzaretto. Evolutionary algorithms for multi-objective energetic and economic optimization in thermal system design. *Energy*, 27(6):549 – 567, 2002.
25. C.A.C. Coello. Handling preferences in evolutionary multiobjective optimization: A survey. In *IEEE Congress on Evolutionary Computation*, pages 30–37, 2000.
26. J. Branke. Consideration of partial user preferences in evolutionary multiobjective optimization. In J. Branke, K. Deb, K. Miettinen, and R. Slowinski, editors, *Multiobjective Optimization, Interactive and Evolutionary Approaches*, volume 5252 of *Lecture Notes in Computer Science*, pages 157–178. Springer, 2008.
27. A. Jaszkiewicz and J. Branke. Interactive multiobjective evolutionary algorithms. In J. Branke, K. Deb, K. Miettinen, and R. Slowinski, editors, *Multiobjective Optimization, Interactive and Evolutionary Approaches*, volume 5252 of *Lecture Notes in Computer Science*, pages 179–193. Springer, 2008.
28. K. Deb and K. Miettinen. Nadir point estimation using evolutionary approaches: Better accuracy and computational speed through focused search. In M. Ehrgott, B. Naujoks, T.J. Stewart, and J. Wallenius, editors, *Multiple Criteria Decision Making for Sustainable Energy and Transportation Systems*, pages 339–354, Berlin, Heidelberg, 2010. Springer.
29. K. Deb., K. Miettinen, and S. Chaudhuri. Towards an estimation of nadir objective vector using a hybrid of evolutionary and local search approaches. *IEEE Transactions on Evolutionary Computation*, 14(6):821–841, 2010.
30. K. Miettinen and M.M. Mäkelä. On scalarizing functions in multiobjective optimization. *OR Spectrum*, 24(2):193–213, 2002.
31. A.P. Wierzbicki. The use of reference objectives in multiobjective optimization. In G. Fandel and T. Gal, editors, *Multiple Criteria Decision Making, Theory and Applications*, pages 468–486. Springer, 1980.
32. K. Miettinen and M.M. Mäkelä. Comparative evaluation of some interactive reference point-based methods for multi-objective optimisation. *Journal of the Operational Research Society*, 50(9):949–959, 1999.
33. J.T. Buchanan and L. Gardiner. A comparison of two reference point methods in multiple objective mathematical programming. *European Journal of Operational Research*, 149(1):17–34, 2003.
34. M. Luque, K. Miettinen, P. Eskelinen, and F. Ruiz. Incorporating preference information in interactive reference point methods for multiobjective optimization. *Omega*, 37(2):450–462, 2009.
35. F. Ruiz, M. Luque, and J.M. Cabello. A classification of the weighting schemes in reference point procedures for multiobjective programming. *Journal of the Operational Research Society*, 60(4):544–553, 2009.